34｜Spark + Kafka：流计算中的“万金油”

2021-11-29 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 18:19 大小 16.78M

你好，我是吴磊。

在前面的几讲中，咱们不止一次提到，就数据源来说，Kafka 是 Structured Streaming 最重要的 Source 之一。在工业级的生产系统中，Kafka 与 Spark 这对组合最为常见。因此，掌握 Kafka 与 Spark 的集成，对于想从事流计算方向的同学来说，是至关重要的。

今天这一讲，咱们就来结合实例，说一说 Spark 与 Kafka 这对“万金油”组合如何使用。随着业务飞速发展，各家公司的集群规模都是有增无减。在集群规模暴涨的情况下，资源利用率逐渐成为大家越来越关注的焦点。毕竟，不管是自建的 Data center，还是公有云，每台机器都是真金白银的投入。

实例：资源利用率实时计算

咱们今天的实例，就和资源利用率的实时计算有关。具体来说，我们首先需要搜集集群中每台机器的资源（CPU、内存）利用率，并将其写入 Kafka。然后，我们使用 Spark 的 Structured Streaming 来消费 Kafka 数据流，并对资源利用率数据做初步的分析与聚合。最后，再通过 Structured Streaming，将聚合结果打印到 Console、并写回到 Kafka，如下图所示。

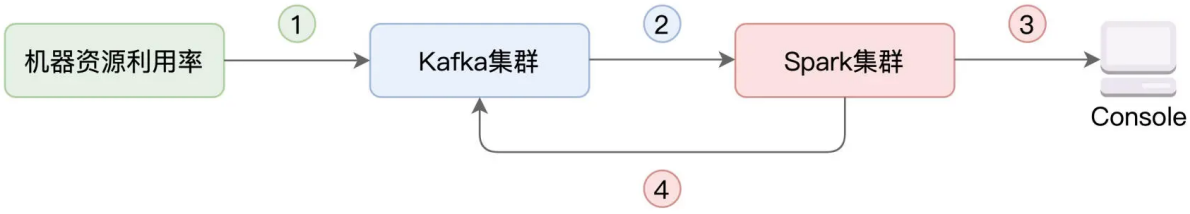

资源利用率实时计算流程图

一般来说，在工业级应用中，上图中的每一个圆角矩形，在部署上都是独立的。绿色矩形代表待监测的服务器集群，蓝色矩形表示独立部署的 Kafka 集群，而红色的 Spark 集群，也是独立部署的。所谓独立部署，它指的是，集群之间不共享机器资源，如下图所示。

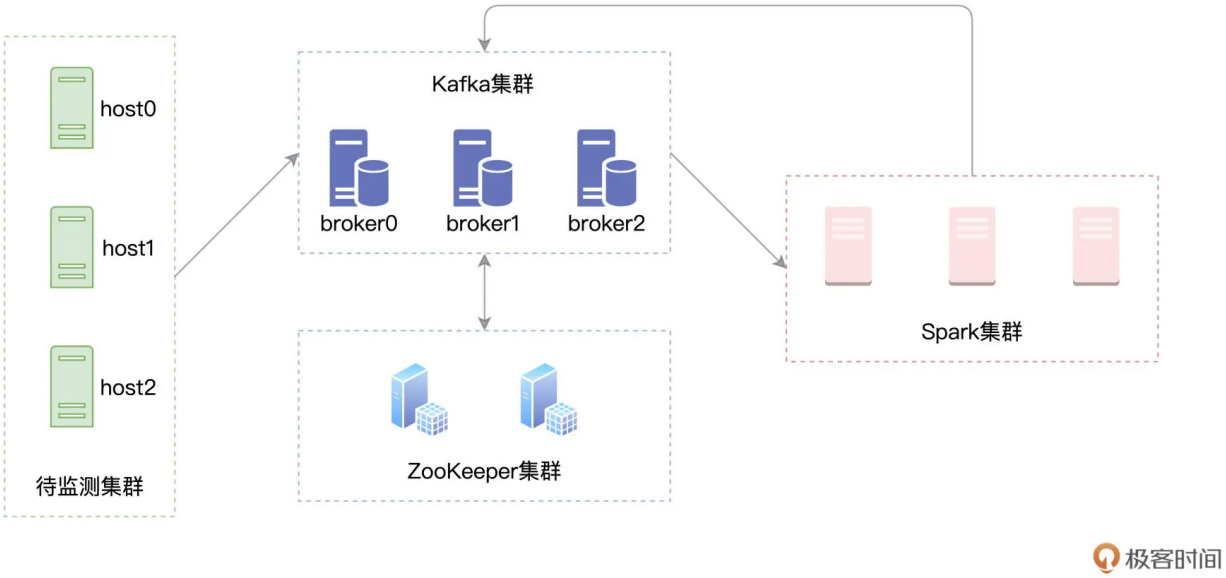

独立部署示意图

如果你手头上没有这样的部署环境，也不用担心。要完成资源利用率实时计算的实例，咱们不必非要依赖独立部署的分布式集群。实际上，仅在单机环境中，你就可以复现今天的实例。

课程安排

今天这一讲涉及的内容比较多，在正式开始课程之前，咱们不妨先梳理一下课程内容，让你做到心中有数。

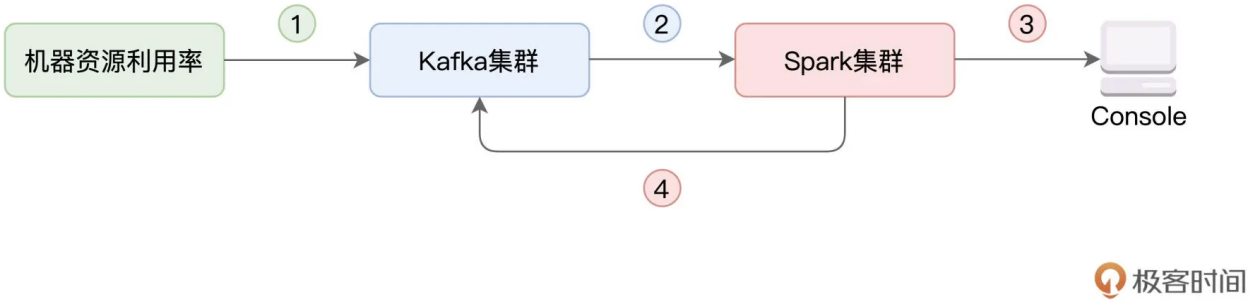

资源利用率实时计算流程图

对于上图的 1、2、3、4 这四个步骤，我们会结合代码实现，分别讲解如下这四个环节：

1. 生成 CPU 与内存消耗数据流，写入 Kafka；

2.Structured Streaming 消费 Kafka 数据，并做初步聚合；

3.Structured Streaming 将计算结果打印到终端；

4.Structured Streaming 将计算结果写回 Kafka，以备后用。

除此之外，为了照顾不熟悉 Kafka 的同学，咱们还会对 Kafka 的安装、Topic 创建与消费、以及 Kafka 的基本概念，做一个简单的梳理。

速读 Kafka 的架构与运行机制

在完成前面交代的计算环节之前，我们需要了解 Kafka 都提供了哪些核心功能。

在大数据的流计算生态中，Kafka 是应用最为广泛的消息中间件（Messaging Queue）。消息中间件的核心功能有以下三点。

1. 连接消息生产者与消息消费者；

2. 缓存生产者生产的消息（或者说事件）；

3. 有能力让消费者以最低延迟访问到消息。

所谓消息生产者，它指的是事件或消息的来源与渠道。在我们的例子中，待监测集群就是生产者。集群中的机器，源源不断地生产资源利用率消息。相应地，消息的消费者，它指的是访问并处理消息的系统。显然，在本讲的例子中，消费者是 Spark。Structured Streaming 读取并处理 Kafka 中的资源利用率消息，对其进行聚合、汇总。

经过前面的分析，我们不难发现，消息中间件的存在，让生产者与消费者这两个系统之间，天然地享有如下三方面的收益。

解耦：双方无需感知对方的存在，二者除了消息本身以外，再无交集；

异步：双方都可以按照自己的“节奏”和“步调”，来生产或是消费消息，而不必受制于对方的处理能力；

削峰：当消费者订阅了多个生产者的消息，且多个生产者同时生成大量消息时，得益于异步模式，消费者可以灵活地消费并处理消息，从而避免计算资源被撑爆的隐患。

好啦，了解了 Kafka 的核心功能与特性之后，接下来，我们说一说 Kafka 的系统架构。与大多数主从架构的大数据组件（如 HDFS、YARN、Spark、Presto、Flink，等等）不同，Kafka 为无主架构。也就是说，在 Kafka 集群中，没有 Master 这样一个角色来维护全局的数据状态。

集群中的每台 Server 被称为 Kafka Broker，Broker 的职责在于存储生产者生产的消息，并为消费者提供数据访问。Broker 与 Broker 之间，都是相互独立的，彼此不存在任何的依赖关系。

如果就这么平铺直叙去介绍 Kafka 架构的话，难免让你昏昏欲睡，所以我们上图解。配合示意图解释 Kafka 中的关键概念，会更加直观易懂。

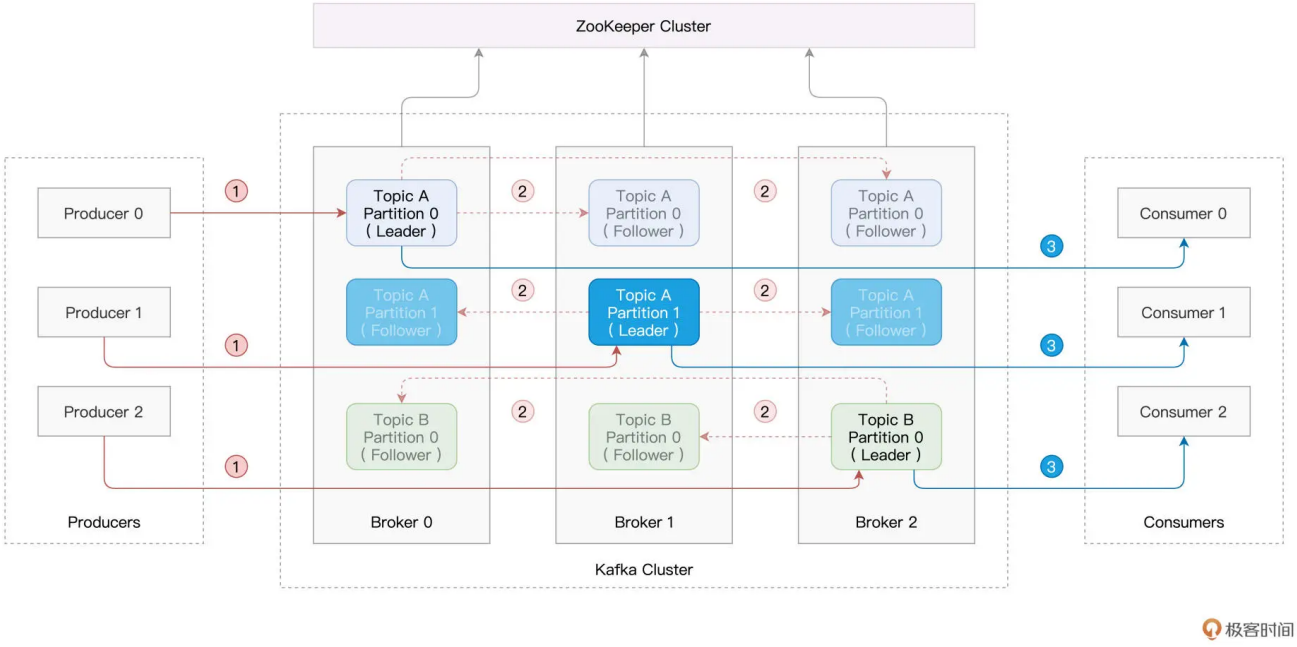

Kafka架构示意图

刚刚说过，Kafka 为无主架构，它依赖 ZooKeeper 来存储并维护全局元信息。所谓元信息，它指的是消息在 Kafka 集群中的分布与状态。在逻辑上，消息隶属于一个又一个的 Topic，也就是消息的话题或是主题。在上面的示意图中，蓝色圆角矩形所代表的消息，全部隶属于 Topic A；而绿色圆角矩形，则隶属于 Topic B。

而在资源利用率的实例中，我们会创建两个 Topic，一个是 CPU 利用率 cpu-monitor，另一个是内存利用率 mem-monitor。**生产者在向 Kafka 写入消息的时候，需要明确指明，消息隶属于哪一个 Topic**。比方说，关于 CPU 的监控数据，应当发往 cpu-monitor，而对于内存的监控数据，则应该发往 mem-monitor。

为了平衡不同 Broker 之间的工作负载，在物理上，同一个 Topic 中的消息，以分区、也就是 Partition 为粒度进行存储，示意图中的圆角矩形，代表的正是一个个数据分区。在 Kafka 中，一个分区，实际上就是磁盘上的一个文件目录。而消息，则依序存储在分区目录的文件中。

为了提供数据访问的高可用（HA，High Availability），在生产者把消息写入主分区（Leader）之后，Kafka 会把消息同步到多个分区副本（Follower），示意图中的步骤 1 与步骤 2 演示了这个过程。

一般来说，消费者默认会从主分区拉取并消费数据，如图中的步骤 3 所示。**而当主分区出现故障、导致数据不可用时，Kafka 就会从剩余的分区副本中，选拔出一个新的主分区来**

对外提供服务，这个过程，又称作“选主”。

好啦，到此为止，Kafka 的基础功能和运行机制我们就讲完了，尽管这些介绍不足以覆盖 Kafka 的全貌，但是，对于初学者来说，这些概念足以帮我们进军实战，做好 Kafka 与 Spark 的集成。

Kafka 与 Spark 集成

接下来，咱们就来围绕着“资源利用率实时计算”这个例子，手把手地带你实现 Kafka 与 Spark 的集成过程。首先，第一步，我们先来准备 Kafka 环境。

Kafka 环境准备

要配置 Kafka 环境，我们只需要简单的三个步骤即可：

1. 安装 ZooKeeper、安装 Kafka，启动 ZooKeeper；

2. 修改 Kafka 配置文件 server.properties，设置 ZooKeeper 相关配置项；

3. 启动 Kafka，创建 Topic。

首先，咱们从ZooKeeper 官网与Kafka 官网，分别下载二者的安装包。然后，依次解压安装包、并配置相关环境变量即可，如下表所示。

复制代码

```
// 下载ZooKeeper安装包
wget https://archive.apache.org/dist/zookeeper/zookeeper-3.7.0/apache-zookeepe
// 下载Kafka安装包
wget https://archive.apache.org/dist/kafka/2.8.0/kafka_2.12-2.8.0.tgz

// 把ZooKeeper解压并安装到指定目录
tar -zxvf apache-zookeeper-3.7.0-bin.tar.gz -C /opt/zookeeper
// 把Kafka解压并安装到指定目录
tar -zxvf kafka_2.12-2.8.0.tgz -C /opt/kafka

// 编辑环境变量
vi ~/.bash_profile
/** 输入如下内容到文件中
export ZOOKEEPER_HOME=/opt/zookeeper/apache-zookeeper-3.7.0-bin
export KAFKA_HOME=/opt/kafka/kafka_2.12-2.8.0
export PATH=$PATH:$ZOOKEEPER_HOME/bin:$KAFKA_HOME/bin
```

```
*/

// 启动ZooKeeper
zkServer.sh start
```

接下来，我们打开 Kafka 配置目录下（也即 $KAFKA_HOME/config）的 server.properties 文件，将其中的配置项 zookeeper.connect，设置为“hostname:2181”，也就是主机名加端口号。

如果你把 ZooKeeper 和 Kafka 安装到同一个节点，那么 hostname 可以写 localhost。而如果是分布式部署，hostname 要写 ZooKeeper 所在的安装节点。一般来说，ZooKeeper 默认使用 2181 端口来提供服务，这里我们使用默认端口即可。

配置文件设置完毕之后，我们就可以使用如下命令，在多个节点启动 Kafka Broker。

复制代码

```
kafka-server-start.sh -daemon $KAFKA_HOME/config/server.properties
```

Kafka 启动之后，咱们就来创建刚刚提到的两个 Topic：cpu-monitor 和 mem-monitor，它们分别用来存储 CPU 利用率消息与内存利用率消息。

复制代码

```
kafka-topics.sh --zookeeper hostname:2181/kafka --create
--topic cpu-monitor
--replication-factor 3
--partitions 1

kafka-topics.sh --zookeeper hostname:2181/kafka --create
--topic mem-monitor
--replication-factor 3
--partitions 1
```

怎么样？是不是很简单？要创建 Topic，只要指定 ZooKeeper 服务地址、Topic 名字和副本数量即可。不过，这里需要特别注意的是，**副本数量，也就是 replication-factor，不能超过集群中的 Broker 数量**。所以，如果你是本地部署的话，也就是所有服务都部署到一台节点，那么这里的 replication-factor 应该设置为 1。

好啦，到此为止，Kafka 环境安装、配置完毕。下一步，我们就该让生产者去生产资源利用率消息，并把消息源源不断地注入 Kafka 集群了。

消息的生产

在咱们的实例中，我们要做的是监测集群中每台机器的资源利用率。因此，我们需要这些机器，每隔一段时间，就把 CPU 和内存利用率发送出来。而要做到这一点，咱们只需要完成一下两个两个必要步骤：

1. 每台节点从本机收集 CPU 与内存使用数据；

2. 把收集到的数据，按照固定间隔，发送给 Kafka 集群。

由于消息生产这部分代码比较长，而我们的重点是学习 Kafka 与 Spark 的集成，因此，这里咱们只给出这两个步骤所涉及的关键代码片段。完整的代码实现，你可以从这里进行下载。

复制代码

```
import java.lang.management.ManagementFactory
import java.lang.reflect.Modifier

def getUsage(mothedName: String): Any = {
// 获取操作系统Java Bean
val operatingSystemMXBean = ManagementFactory.getOperatingSystemMXBean
// 获取操作系统对象中声明过的方法
    for (method <- operatingSystemMXBean.getClass.getDeclaredMethods) {
      method.setAccessible(true)
// 判断是否为我们需要的方法名
      if (method.getName.startsWith(mothedName) && Modifier.isPublic(method.ge
// 调用并执行方法，获取指定资源（CPU或内存）的利用率
        return method.invoke(operatingSystemMXBean)
      }
    }
    throw new Exception(s"Can not reflect method: ${mothedName}")
  }

// 获取CPU利用率
def getCPUUsage(): String = {
    var usage = 0.0
try{
// 调用getUsage方法，传入"getSystemCpuLoad"参数，获取CPU利用率
      usage = getUsage("getSystemCpuLoad").asInstanceOf[Double] * 100
    } catch {
```

```
      case e: Exception => throw e
    }
    usage.toString
  }

// 获取内存利用率
def getMemoryUsage(): String = {
    var freeMemory = 0L
    var totalMemory = 0L
    var usage = 0.0
try{
// 调用getUsage方法，传入相关内存参数，获取内存利用率
      freeMemory = getUsage("getFreePhysicalMemorySize").asInstanceOf[Long]
      totalMemory = getUsage("getTotalPhysicalMemorySize").asInstanceOf[Long]
// 用总内存，减去空闲内存，获取当前内存用量
      usage = (totalMemory - freeMemory.doubleValue) / totalMemory * 100
    } catch {
      case e: Exception => throw e
    }
    usage.toString
  }
```

利用 Java 的反射机制，获取资源利用率

上面的代码，用来获取 CPU 与内存利用率。在这段代码中，最核心的部分是利用 Java 的反射机制，来获取操作系统对象的各个公有方法，然后通过调用这些公有方法，来完成资源利用率的获取。

不过，看到这你可能会说：“我并不了解 Java 的反射机制，上面的代码看不太懂。”这也没关系，只要你能结合注释，把上述代码的计算逻辑搞清楚即可。获取到资源利用率的数据之后，接下来，我们就可以把它们发送给 Kafka 了。

复制代码

```
import org.apache.kafka.clients.producer.{Callback, KafkaProducer, ProducerCon
import org.apache.kafka.common.serialization.StringSerializer

// 初始化属性信息
  def initConfig(clientID: String): Properties = {
    val props = new Properties
val brokerList = "localhost:9092"
// 指定Kafka集群Broker列表
    props.put(ProducerConfig.BOOTSTRAP_SERVERS_CONFIG, brokerList)
    props.put(ProducerConfig.KEY_SERIALIZER_CLASS_CONFIG, classOf[StringSerial
    props.put(ProducerConfig.VALUE_SERIALIZER_CLASS_CONFIG, classOf[StringSeri
    props.put(ProducerConfig.CLIENT_ID_CONFIG, clientID)
```

```
    props
  }

val clientID = "usage.monitor.client"
    val cpuTopic = "cpu-monitor"
    val memTopic = "mem-monitor"

// 定义属性，其中包括Kafka集群信息、序列化方法，等等
val props = initConfig(clientID)
// 定义Kafka Producer对象，用于发送消息
val producer = new KafkaProducer[String, String](props)
// 回调函数，可暂时忽略
    val usageCallback = _

    while (true) {
      var cpuUsage = new String
      var memoryUsage = new String
// 调用之前定义的函数，获取CPU、内存利用率
      cpuUsage = getCPUUsage()
      memoryUsage = getMemoryUsage()

// 为CPU Topic生成Kafka消息
      val cpuRecord = new ProducerRecord[String, String](cpuTopic, clientID, c
// 为Memory Topic生成Kafka消息
      val memRecord = new ProducerRecord[String, String](memTopic, clientID, m
// 向Kafka集群发送CPU利用率消息
      producer.send(cpuRecord, usageCallback)
// 向Kafka集群发送内存利用率消息
      producer.send(memRecord, usageCallback)
// 设置发送间隔：2秒
      Thread.sleep(2000)
    }
```

从上面的代码中，我们不难发现，其中的关键步骤有三步：

定义 Kafka Producer 对象，其中需要我们在属性信息中，指明 Kafka 集群相关信息；

调用之前定义的函数 getCPUUsage、getMemoryUsage，获取 CPU 与内存资源利用率；

把资源利用率封装为消息，并发送给对应的 Topic。

好啦，到此为止，生产端的事情，我们就全部做完啦。在待监测的集群中，每隔两秒钟，每台机器都会向 Kafka 集群的 cpu-monitor 和 mem-monitor 这两个 Topic 发送即时消息。Kafka 接收到这些消息之后，会把它们落盘到相应的分区中，等待着下游（也就是 Spark）的消费。

消息的消费

接下来，终于要轮到 Structured Streaming 闪亮登场了。在流计算模块的第一讲，我们就提到，Structured Streaming 支持多种 Source（Socket、File、Kafka），而在这些 Source 中，Kafka 的应用最为广泛。在用法上，相比其他 Source，从 Kafka 接收并消费数据并没有什么两样，咱们依然是依赖“万能”的 readStream API，如下表所示。

复制代码

```
import org.apache.spark.sql.DataFrame

// 依然是依赖readStream API
val dfCPU:DataFrame = spark.readStream
// format要明确指定Kafka
.format("kafka")
// 指定Kafka集群Broker地址，多个Broker用逗号隔开
.option("kafka.bootstrap.servers", "hostname1:9092,hostname2:9092,hostname3:90
// 订阅相关的Topic，这里以cpu-monitor为例
.option("subscribe", "cpu-monitor")
.load()
```

对于 readStream API 的用法，想必你早已烂熟于心了，上面的代码，你应该会觉得看上去很眼熟。这里需要我们特别注意的，主要有三点：

format 中需要明确指定 Kafka；

为 kafka.bootstrap.servers 键值指定 Kafka 集群 Broker，多个 Broker 之间以逗号分隔；

为 subscribe 键值指定需要消费的 Topic 名，明确 Structured Streaming 要消费的 Topic。

挥完上面的“三板斧”之后，我们就得到了用于承载 CPU 利用率消息的 DataFrame。有了 DataFrame，我们就可以利用 Spark SQL 提供的能力，去做各式各样的数据处理。再者，结合 Structured Streaming 框架特有的 Window 和 Watermark 机制，我们还能以时间窗口为粒度做计数统计，同时决定“多迟”的消息，我们将不再处理。

不过，在此之前，咱们不妨先来直观看下代码，感受一下存在 Kafka 中的消息长什么样子。

复制代码

```
import org.apache.spark.sql.streaming.{OutputMode, Trigger}
import scala.concurrent.duration._

dfCPU.writeStream
.outputMode("Complete")
// 以Console为Sink
.format("console")
// 每10秒钟，触发一次Micro-batch
.trigger(Trigger.ProcessingTime(10.seconds))
.start()
.awaitTermination()
```

利用上述代码，通过终端，我们可以直接观察到 Structured Streaming 获取的 Kafka 消息，从而对亟待处理的消息，建立一个感性的认知，如下图所示。

```
-------------------------------------------
Batch: 1
-------------------------------------------
+--------------------+--------------------+-----------+---------+------+--------------------+-------------+
|                 key|               value|      topic|partition|offset|           timestamp|timestampType|
+--------------------+--------------------+-----------+---------+------+--------------------+-------------+
|[63 6C 69 65 6E 7...|[35 2E 32 39 33 3...|cpu-monitor|        0|  5127|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[35 2E 34 36 35 3...|cpu-monitor|        0|  5128|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[35 2E 37 30 30 3...|cpu-monitor|        0|  5129|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[39 2E 32 33 35 3...|cpu-monitor|        0|  5130|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[39 2E 30 36 32 3...|cpu-monitor|        0|  5131|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[38 2E 38 32 36 3...|cpu-monitor|        0|  5132|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[30 2E 30 33 31 3...|cpu-monitor|        0|  5133|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[30 2E 30 34 36 3...|cpu-monitor|        0|  5134|2021-11-21 13:29:...|            0|
|[63 6C 69 65 6E 7...|[30 2E 30 34 36 3...|cpu-monitor|        0|  5135|2021-11-21 13:29:...|            0|
+--------------------+--------------------+-----------+---------+------+--------------------+-------------+
```

CPU利用率消息示例

在上面的数据中，除了 Key、Value 以外，其他信息都是消息的元信息，也即消息所属 Topic、所在分区、消息的偏移地址、录入 Kafka 的时间，等等。

在咱们的实例中，Key 对应的是发送资源利用率数据的服务器节点，而 Value 则是具体的 CPU 或是内存利用率。初步熟悉了消息的 Schema 与构成之后，接下来，咱们就可以有的放矢地去处理这些实时的数据流了。

对于这些每两秒钟就产生的资源利用率数据，假设我们仅关心它们在一定时间内（比如 10 秒钟）的平均值，那么，我们就可以结合 Trigger 与聚合计算来做到这一点，代码如下所示。

复制代码

```
import org.apache.spark.sql.types.StringType

```

```
dfCPU
.withColumn("clientName", $"key".cast(StringType))
.withColumn("cpuUsage", $"value".cast(StringType))
// 按照服务器做分组
.groupBy($"clientName")
// 求取均值
.agg(avg($"cpuUsage").cast(StringType).alias("avgCPUUsage"))
.writeStream
.outputMode("Complete")
// 以Console为Sink
.format("console")
// 每10秒触发一次Micro-batch
.trigger(Trigger.ProcessingTime(10.seconds))
.start()
.awaitTermination()
```

可以看到，我们利用 Fixed interval trigger，每隔 10 秒创建一个 Micro-batch。然后，在一个 Micro-batch 中，我们按照发送消息的服务器做分组，并计算 CPU 利用率平均值。最后将统计结果打印到终端，如下图所示。

```
-------------------------------------------
Batch: 1
-------------------------------------------
+----------+--------------------+
|clientName|          avgCPUUsage|
+----------+--------------------+
|  client02|24.050370216852713|
|  client03| 24.116581402716668|
|  client01|24.088094123770023|
+----------+--------------------+
```

统计CPU利用率均值

再次写入 Kafka

实际上，除了把结果打印到终端外，我们还可以把它写回 Kafka。我们知道 Structured Streaming 支持种类丰富的 Sink，除了常用于测试的 Console 以外，还支持 File、Kafka、Foreach(Batch)，等等。要把数据写回 Kafka 也不难，我们只需在 writeStream API 中，指定 format 为 Kafka 并设置相关选项即可，如下表所示。

复制代码

```
dfCPU
.withColumn("key", $"key".cast(StringType))
.withColumn("value", $"value".cast(StringType))
.groupBy($"key")
.agg(avg($"value").cast(StringType).alias("value"))
.writeStream
.outputMode("Complete")
// 指定Sink为Kafka
.format("kafka")
// 设置Kafka集群信息，本例中只有localhost一个Kafka Broker
.option("kafka.bootstrap.servers", "localhost:9092")
// 指定待写入的Kafka Topic，需事先创建好Topic：cpu-monitor-agg-result
.option("topic", "cpu-monitor-agg-result")
// 指定WAL Checkpoint目录地址
.option("checkpointLocation", "/tmp/checkpoint")
.trigger(Trigger.ProcessingTime(10.seconds))
.start()
.awaitTermination()
```

我们首先指定 Sink 为 Kafka，然后通过 option 选项，分别设置 Kafka 集群信息、待写入的 Topic 名字，以及 WAL Checkpoint 目录。将上述代码敲入 spark-shell，Structured Streaming 会每隔 10 秒钟，就从 Kafka 拉取原始的利用率信息（Topic：cpu-monitor），然后按照服务器做分组聚合，最终再把聚合结果写回到 Kafka（Topic：cpu-monitor-agg-result）。

这里有两点需要特别注意，一个是**读取与写入的 Topic 要分开，以免造成逻辑与数据上的混乱**。再者，细心的你可能已经发现，**写回 Kafka 的数据，在 Schema 上必须用“key”和“value”这两个固定的字段**，而不能再像写入 Console 时，可以灵活地定义类似于“clientName”和“avgCPUUsage”这样的字段名，关于这一点，还需要你特别关注。

重点回顾

好啦，到此为止，我手把手地带你实现了 Kafka 与 Spark 的集成，完成了图中涉及的每一个环节，也即从消息的生产、到写入 Kafka，再到消息的消费与处理，并最终写回 Kafka。

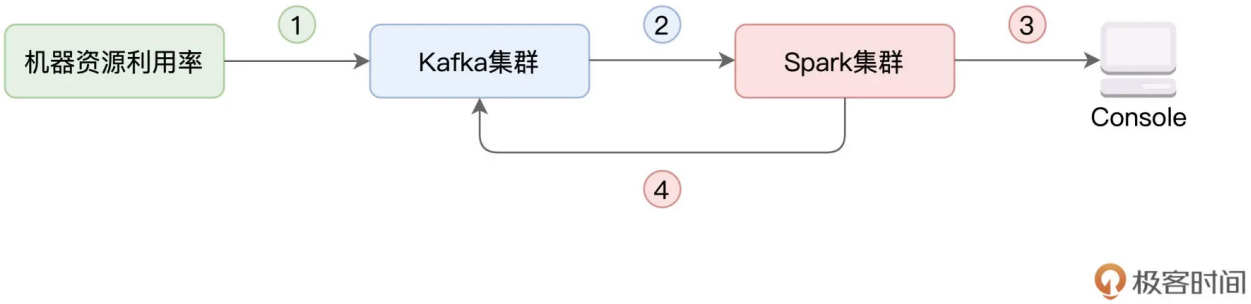

资源利用率实时计算流程图

今天的内容比较多，你除了需要掌握集成中的每一个环节与用法外，还需要了解一些有关 Kafka 的基本概念与特性。Kafka 是应用最为广泛的消息中间件（Messaging Queue），它的核心功能有三个：

1. 连接消息生产者与消息消费者；

2. 缓存生产者生产的消息（或者说事件）；

3. 有能力让消费者以最低延迟访问到消息。

对于 Kafka 的一些基本概念，你无需死记硬背，在需要的时候，回顾后面这张架构图即可。这张图中，清楚地标记了 Kafka 的基础概念，以及消息生产、缓存与消费的简易流程。

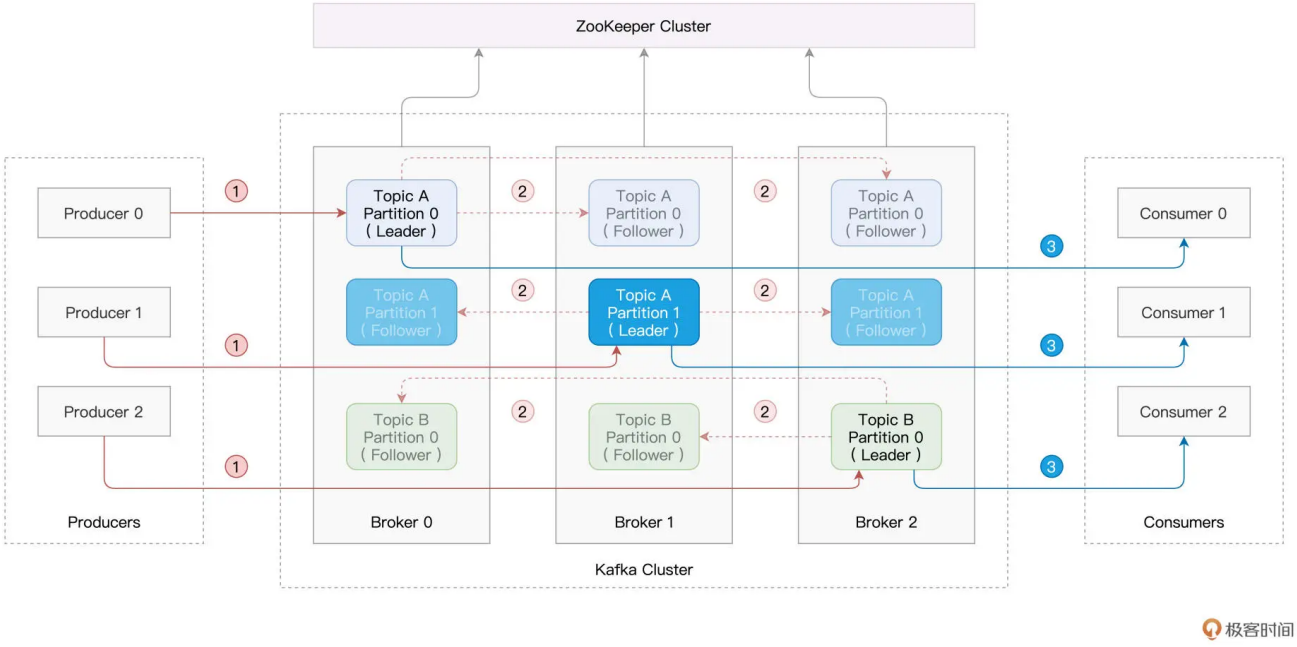

Kafka架构示意图

而对于 Kafka 与 Spark 两者的集成，不管是 Structured Streaming 通过 readStream API 消费 Kafka 消息，还是使用 writeStream API 将计算结果写入 Kafka，你只需要记住如下几点，即可轻松地搭建这对“万金油”组合。

在 format 函数中，指定 Kafka 为 Source 或 Sink；

在 option 选项中，为 kafka.bootstrap.servers 键值指定 Kafka 集群 Broker；

在 option 选项中，设置 subscribe 或是 topic，指定读取或是写入的 Kafka Topic。

每课一练

请你结合本讲中 CPU 利用率的代码，针对内存利用率，完成示意图中的各个环节，也即内存利用率消息的生产、写入 Kafka（步骤 1）、消息的消费与计算（步骤 2、3），聚合结果再次写入 Kafka（步骤 4）。

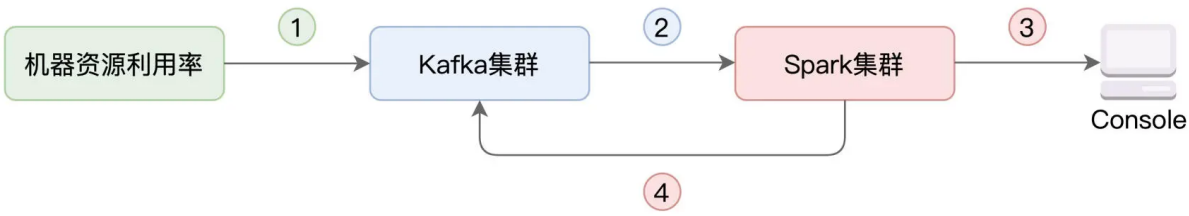

欢迎你把今天这讲内容转发给更多同事、朋友，跟他一起动手试验一下 Spark + Kafka 的实例，我再留言区等你分享。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 2 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 33 | 流计算中的数据关联：流与流、流与批

下一篇 用户故事 | 小王：保持空杯心态，不做井底之蛙

更多学习推荐

精选留言

写留言

> 由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。